

Третий семинар. ММП, осень 2012–2013 2 октября

Темы семинара:

- Байесовская классификация;
- Нормальный дискриминантный анализ;
- Линейный дискриминант Фишера.

1 Первая половина

Начнем с короткого резюме вероятностной постановки, среднего риска классификатора и байесовского решающего правила

$$a(x) = \arg \max_{y \in \mathbb{Y}} \lambda_y P_y p(x|y).$$

Это случай, когда штраф зависит только от истинной классификации объекта. Коротко вспоминаем, что такое апостериорная вероятность и формулируем байесовский классификатор в его терминах.

Есть много способов оценивать плотность классов, сегодня будем говорить о нормальном дискриминантном анализе: мы будем полагать, что все классы имеют многомерное нормальное распределение. Это пример параметрического подхода к оценке плотности.

Задача 1. Объекты двух классов $Y = \{-1, +1\}$ описываются точкой действительной оси $X = \mathbb{R}$. Априорные вероятности классов равны $P(Y = +1) = P(Y = -1) = 0.5$, величины потерь при ошибочной классификации одинаковы $\lambda_{+1,-1} = \lambda_{-1,+1}$, а при правильной классификации равны нулю $\lambda_{+1,+1} = \lambda_{-1,-1} = 0$. $p_1(x), p_2(x)$ — функции правдоподобия классов $+1$ и -1 соответственно. Выписать формулу Байесовского классификатора в явном виде, если:

1. $p_1(x)$ и $p_2(x)$ — гладкие функции, не касающиеся друг друга ни в одной точке, имеющие ровно n точек пересечения: $x_1 < x_2 < \dots < x_n$.
2. $p_1(x) \equiv \mathcal{N}(0, 1)$, а $p_2(x) \equiv \mathcal{N}(0, 2z)$, где z — квантиль стандартного нормального распределения уровня 95%. Вычислите также байесовский уровень ошибки.

Дальше вкратце вспоминаем, что такое декорелирующее преобразование координат, и как выглядят линии уровня многомерного нормального распределения.

Задача 2. Каждый из двух классов имеет 2-мерное нормальное распределение со средними $\mu_1 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$, $\mu_2 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ и ковариационными матрицами $\Sigma_1 = \Sigma_2 = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$. Априорные вероятности классов $P_1 = 1/3$, $P_2 = 2/3$. Штрафы за ошибочную классификацию равны.

а) Найдите оси симметрии линий уровня любой из функции правдоподобия классов.
б) Запишите функцию правдоподобия в новых координатах. Что это за преобразование? Какие полезные свойства вы в нем видите?

в) Выпишите аналитическую форму разделющей поверхности байесовского классификатора в новых декорелизованных координатах. Запишите поверхность в исходных координатах.

Решение. а) $\begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix} = \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix} \begin{pmatrix} 3 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix}$

б) Запишем ф.п. для второго класса:

$$p_2(x) = \frac{1}{2\pi\sqrt{3}} \exp\left\{-\frac{1}{2}(t - \mu')^\top \begin{pmatrix} 1/3 & 0 \\ 0 & 1 \end{pmatrix} (t - \mu')\right\};$$

$$t = \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}; \quad \mu' = \begin{pmatrix} 1/\sqrt{2} & 1/\sqrt{2} \\ 1/\sqrt{2} & -1/\sqrt{2} \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} \sqrt{2} \\ 0 \end{pmatrix}.$$

в)

$$\ln(1/3) + C - \frac{1}{2} \left(\frac{t_1^2}{3} + t_2^2 \right) = \ln(2/3) + C - \frac{1}{2} \left(\frac{(t_1 - \sqrt{2})^2}{3} + t_2^2 \right),$$

или

$$t_1 = \frac{1 - 3 \ln 2}{\sqrt{2}}.$$

2 Вторая половина

2.1 Другой взгляд на ЛДФ. (Bishop, p. 186)

В лекции К. В. Воронцова ЛДФ вводится с положения ковариационных матриц классов равными и последовательным ее оцениванием с помощью обучающей выборки $\{(x_i, y_i)\}_{i=1}^\ell$, $x_i \in \mathbb{R}^d$, $y_i \in \mathbb{Y}$:

$$\hat{\Sigma} = \frac{1}{\ell} \sum_{i=1}^{\ell} (x_i - \hat{\mu}_{y_i})(x_i - \hat{\mu}_{y_i})^\top,$$

где $\hat{\mu}_y$ — среднее выборочное значение объектов из класса $y \in \mathbb{Y}$. Эту эвристiku, оказывается, можно обосновать несколькими способами. Приведем одну из постановок задач, которая ведет к получению тех же результатов.

Рассмотрим задачу классификации с двумя классами $\mathbb{Y} = \{1, 2\}$ и попробуем решать ее с помощью линейной проекции объектов обучающей выборки на прямую: $t_i = w^\top x_i$, $w \in \mathbb{R}^d$. Выбрав порог w_0 , мы можем принимать решение о классификации, сравнивая с ним t_i .

Очевидно, выбор w , основанный на максимальном удалении проекций средних выборочных значений классов, имеет недостатки. Предложим другой подход. Определим s_1^2 и s_2^2 — *внутреклассные дисперсии* проекций:

$$s_1^2 = \sum_{y_i=1} (t_i - m_1)^2; \quad s_2^2 = \sum_{y_i=2} (t_i - m_2)^2$$

$$m_1 = \frac{1}{\ell_1} \sum_{y_i=1} t_i \equiv w^\top \hat{\mu}_1; \quad m_2 = \frac{1}{\ell_1} \sum_{y_i=2} t_i \equiv w^\top \hat{\mu}_2.$$

Полной внутреклассной дисперсией назовем сумму $s_1^2 + s_2^2$. Нашей целью будет максимизировать отношение *межклассовой дисперсии* $(m_2 - m_1)^2$ и полной внутреклассовой:

$$J(w) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2} \rightarrow \max_{w \in \mathbb{R}^d}.$$

Распишем все величины с помощью w :

$$J(w) = \frac{(w^\top (\hat{\mu}_2 - \hat{\mu}_1))^2}{\sum_{y_i=1} (w^\top x_i - w^\top \hat{\mu}_1)^2 + \sum_{y_i=2} (w^\top x_i - w^\top \hat{\mu}_2)^2} =$$

$$= \frac{w^\top (\hat{\mu}_2 - \hat{\mu}_1)(\hat{\mu}_2 - \hat{\mu}_1)^\top w}{\sum_{y_i=1} w^\top (x_i - \hat{\mu}_1)(x_i - \hat{\mu}_1)^\top w + \sum_{y_i=2} w^\top (x_i - \hat{\mu}_2)(x_i - \hat{\mu}_2)^\top w} =$$

$$= \frac{w^\top (\hat{\mu}_2 - \hat{\mu}_1)(\hat{\mu}_2 - \hat{\mu}_1)^\top w}{w^\top \left(\sum_{y_i=1} (x_i - \hat{\mu}_1)(x_i - \hat{\mu}_1)^\top + \sum_{y_i=2} (x_i - \hat{\mu}_2)(x_i - \hat{\mu}_2)^\top \right) w}.$$

Обозначим

$$S_b = (\hat{\mu}_2 - \hat{\mu}_1)(\hat{\mu}_2 - \hat{\mu}_1)^\top;$$

$$S_w = \left(\sum_{y_i=1} (x_i - \hat{\mu}_1)(x_i - \hat{\mu}_1)^\top + \sum_{y_i=2} (x_i - \hat{\mu}_2)(x_i - \hat{\mu}_2)^\top \right),$$

тогда

$$J(w) = \frac{w^\top S_b w}{w^\top S_w w}.$$

Нам остается приравнять производную того выражения по w нулю:

$$\frac{w^\top S_w w (S_b^\top w + S_b w) - w^\top S_b w (S_w^\top w + S_w w)}{(w^\top S_w w w)^2} = 0$$

Поскольку обе матрицы S_b и S_w симметричны, то приходим к уравнению

$$(w^\top S_w w) S_b w = (w^\top S_b w) S_w w.$$

Заметим, что $S_b w \propto \hat{\mu}_2 - \hat{\mu}_1$, поэтому приходим к

$$w \propto S_w^{-1}(\hat{\mu}_2 - \hat{\mu}_1).$$

Таким образом, максимизируя функционал $J(w)$, мы получили ту же самую нормаль разделяющей поверхности, как в предположении совпадающих ковариационных матриц в рамках нормального дискриминантного анализа.

2.2 ЛДФ vs МНК (Bishop, p. 189), (Tibshirani ex. 4.2)

Мы снова рассматриваем задачу классификации с $\mathbb{X} = \mathbb{R}^d$. Покажем, что в случае двух классов $\mathbb{Y} = \{1, 2\}$ между ЛДФ и МНК при особом выборе ответов на объектах обучающей выборки есть прямая связь.

МНК, как мы знаем, используется, как правило, в задачах восстановления регрессии и стремится уменьшить квадратичную ошибку на обучающей выборке. Рассмотрим следующую задачу регрессии, полученную из рассматриваемой задачи классификации: положим ответы t_i на объектах обучающей выборки класса 1 и 2 равными ℓ/ℓ_1 и $-\ell/\ell_2$ соответственно. Нашей целью будет поиск вектора весов $w \in \mathbb{R}^d$ и константы w_0 , минимизирующих среднеквадратичный риск на обучающей выборке:

$$\frac{1}{2} \sum_{i=1}^{\ell} (w^\top x_i + w_0 - t_i)^2 \rightarrow \min_{w, w_0}.$$

Приравняв производные по w и w_0 нулю, получаем:

$$\sum_{i=1}^{\ell} (w^\top x_i + w_0 - t_i) = 0; \quad (1)$$

$$\sum_{i=1}^{\ell} (w^\top x_i + w_0 - t_i) x_i = 0. \quad (2)$$

Из первого равенства с учетом $\sum_i t_i = 0$ получаем $w_0 = -w^\top \mu$, где μ — среднее выборочное объектов и

$$\mu \equiv \frac{\ell_1}{\ell} \mu_1 + \frac{\ell_2}{\ell} \mu_2.$$

Поскольку

$$\sum_{i=1}^{\ell} t_i x_i = \frac{\ell}{\ell_1} \sum_{y_i=1} x_i - \frac{\ell}{\ell_2} \sum_{y_i=2} x_i = \ell(\mu_1 - \mu_2),$$

то второе равенство преобразуется к виду

$$\sum_{i=1}^{\ell} (w^\top x_i + w_0) x_i = \ell(\mu_1 - \mu_2).$$

Продолжим работу с левой частью последнего равенства:

$$\sum_{i=1}^{\ell} (w^\top x_i + w_0) x_i = \sum_{i=1}^{\ell} (w^\top x_i - w^\top \mu) x_i = \sum_{i=1}^{\ell} x_i (x_i - \mu)^\top w = Mw,$$

где $M \in \mathbb{R}^{d \times d}$ — некоторая матрица. Докажем, что $M = S_w + \frac{\ell_1 \ell_2}{\ell} S_b$. Будем вести

цепочку неравенств в обратную сторону:

$$\begin{aligned}
S_w + \frac{\ell_1 \ell_2}{\ell} S_b &= \sum_{y_i=1} (x_i - \mu_1)(x_i - \mu_1)^\top + \sum_{y_2=1} (x_i - \mu_2)(x_i - \mu_2)^\top + \frac{\ell_1 \ell_2}{\ell} S_b = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top + \ell_1 \mu_1 \mu_1^\top + \ell_2 \mu_2 \mu_2^\top - \sum_{y_i=1} x_i \mu_1^\top - \sum_{y_i=1} \mu_1 x_i^\top - \sum_{y_i=2} x_i \mu_2^\top - \sum_{y_i=2} \mu_2 x_i^\top + \frac{\ell_1 \ell_2}{\ell} S_b = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top + \ell_1 \mu_1 \mu_1^\top + \ell_2 \mu_2 \mu_2^\top - 2\ell_1 \mu_1 \mu_1^\top - 2\ell_2 \mu_2 \mu_2^\top + \frac{\ell_1 \ell_2}{\ell} S_b = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top - \ell_1 \mu_1 \mu_1^\top - \ell_2 \mu_2 \mu_2^\top + \frac{\ell_1 \ell_2}{\ell} (\mu_2 - \mu_1)(\mu_2 - \mu_1)^\top = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top - \frac{\ell_1 \ell_2}{\ell} (\mu_2 \mu_1^\top + \mu_1 \mu_2^\top) + \frac{\ell_1 \ell_2 - \ell_2 \ell}{\ell} \mu_2 \mu_2^\top + \frac{\ell_1 \ell_2 - \ell_1 \ell}{\ell} \mu_1 \mu_1^\top = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top - \frac{\ell_1 \ell_2}{\ell} (\mu_2 \mu_1^\top + \mu_1 \mu_2^\top) - \frac{\ell_2^2}{\ell} \mu_2 \mu_2^\top - \frac{\ell_1^2}{\ell} \mu_1 \mu_1^\top = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top - \frac{1}{\ell} (\ell_1 \mu_1 + \ell_2 \mu_2)(\ell_1 \mu_1^\top + \ell_2 \mu_2^\top) = \sum_{i=1}^{\ell} x_i x_i^\top - (\ell_1 \mu_1 + \ell_2 \mu_2)\mu^\top = \\
&= \sum_{i=1}^{\ell} x_i x_i^\top - \sum_{i=1}^{\ell} x_i \mu^\top = \sum_{i=1}^{\ell} x_i (x_i - \mu)^\top = M.
\end{aligned}$$

Таким образом, уравнение (2) переписывается в виде

$$(S_w + \frac{\ell_1 \ell_2}{\ell} S_b)w = \ell(\mu_1 - \mu_2).$$

Снова, поскольку $S_b w \propto (\mu_2 - \mu_1)$, то получаем

$$w \propto S_w^{-1}(\mu_2 - \mu_1).$$

Таким образом, нормали к гиперплоскостям для ЛДФ и МНК для описанной задачи регрессии параллельны. Однако отметим, что свободные члены w_0 в общем случае не совпадают. Как правило, свободный член можно выбрать исходя из соображений хорошего риска на обучающей выборке. МНК не использует предположения о нормальности распределений классов, таким образом описанный подход можно применять и в более общих случаях, когда никакой нормальности нет.

3 Проверочная

- 1.а. Выведите оценку максимального правдоподобия для среднего одномерного нормального распределения.
- 1.б. Выведите оценку максимального правдоподобия для параметра p распределения Бернулли.
- 2.а. Вычислите дисперсию биномиального распределения.
- 2.б. Вычислите матожидание биномиального распределения.
3. Напишите формулу плотности n -мерного нормального распределения.

4 Домашнее задание

1. Пусть два класса имеют n -мерные нормальные распределения со средними μ_1 и μ_2 и одинаковыми ковариационными матрицами Σ . Докажите, что разделяющая поверхность байесовского классификатора проходит через середину отрезка, соединяющего средние значения двух классов, параллельно линиям уровня функций правдоподобия классов.
2. Два класса имеют двухмерные нормальные плотности с параметрами (μ_1, Σ_1) и (μ_2, Σ_2) . Априорные вероятности классов — P_1 и P_2 . Величины потерь при неправильной классификации — λ_1 и λ_2 .
 - а) Найдите вид байесовской разделяющей поверхности, если $\Sigma_1 = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$, $\Sigma_2 = \begin{pmatrix} 3 & -2 \\ -2 & 3 \end{pmatrix}$, $\mu_1 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$, $\mu_2 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$, $P_1 = P_2 = \frac{1}{2}$, $\lambda_1 = \lambda_2$;
 - б) При каких параметрах задачи разделяющей поверхностью байесовского классификатора будет пара параллельных прямых?